Reconstrução de Imagens de Tomografia por Impedância Elétrica baseada em Redes Neurais Convolucionais *

Guilherme C. Duran^{**,*} André K. Sato^{***,*} Naser Tanabi^{****,*} Hossein Nasiri^{†,*} Rogério Y. Takimoto^{‡,*} Thiago C. Martins^{§,*} Marcos S. G. Tsuzuki^{|,*}

* Laboratory of Computational Geometry Mechatronics and Mechanical Systems Engineering Department, Escola Politécnica da Universidade de São Paulo, São Paulo, Brazil

** e-mail: guiduran@usp.br
*** e-mail: andre.kubagawa@gmail.com
 **** e-mail: n.tanabi@gmail.com
 † e-mail: h.nasiri.ir@gmail.com
 [†] e-mail: takimotoyugo@gmail.com
 [§] e-mail: thiago@usp.br
 [†] e-mail: mtsuzuki@usp.br

Abstract: Electrical tomography impedance is a technique for generating images of the interior region of a body based on the measure of the potentials along the surface after a small amplitude current injection. Several techniques were employed to process EIT images, but, in general, these are indirect methods and, consequentially, have perfomance issues. In order to overcome such difficulty, artificial neural networks (ANNs) have been used recently. In this work, a solution which employs a LeNet based ANN is proposed. Finite element method meshes with different discretizations are used to solve the EIT forward problem and the conductivity distribution reconstruction so as to allow a better precision control of the result. Reconstruction of a set of artificially generated data showed satisfactory results after a visual inspection and also presented small mean squared error for a small test dataset.

Resumo: A Tomografia por Impedância Elétrica é uma técnica de reconstrução de imagens do interior de um corpo que utiliza da medição de potenciais elétricos em superfícies obtidos a partir da injeção de uma corrente de baixa amplitude. Diversos métodos foram utilizados para a reconstrução de imagens com TIE, mas, em geral, os métodos são indiretos e, consequentemente, apresentam baixo desempenho. A fim de contornar esse problema, entre as abordagens mais recentes está a aplicação das Redes Neurais Artificiais. Neste trabalho propõe-se a utilização de Redes Neurais Convolucionais baseadas na arquitetura da rede LeNet. Malhas de elementos finitos de diferentes resoluções são utilizadas para a resolução do problema direto e da reconstrução da distribuição de condutividade a fim de possibilitar uma maior precisão na solução do problema direto. Os resultados da reconstrução de imagens para um conjunto de dados sintéticos mostraram-se bastante satisfatórios a partir de uma avaliação visual e da determinação do erro quadrático médio para um pequeno conjunto de dados de testes.

Keywords: Electrical impedance tomography; Convolutional neural networks. *Palavras-chaves:* Tomografia por impedância elétrica; Redes neurais convolucionais.

1. INTRODUÇÃO

A Tomografia por Impedância Elétrica (TIE) consiste em um método indireto para a reconstrução de imagens do interior de um corpo ou objeto. Entre as vantagens da TIE sobre outros métodos não invasivos estão os fatos de que ela não depende da emissão de radiação e de que o equipamento utilizado pode ser pequeno e portátil, com custo relativamente baixo. A TIE tem sido usada para monitoramento em tempo real de processos industriais e de análise biomédica (Martins and Tsuzuki, 2012; Silva et al., 2017).

O processo de reconstrução de imagens consiste em converter uma propriedade física do corpo em um valor em escala de cinza, para que então possa ser renderizado como uma

^{*} Este projeto foi suportado pelo CNPq (proc. 433.151/2018–8), FAPESP (proc. 2017/07799–5) e NAP TIE-US (USP). N. Tanabi, H. Nasiri e A. K. Sato são suportados pela FUSP/Petrobras. M. S. G. Tsuzuki and Thiago C. Martins foram parcialmente suportados pelo CNPq (proc. 305.959/2016–6 e 311.195/2019-9). G. C. Duran é suportado pelo CNPq.

imagem. No caso da TIE, a propriedade é a impedância elétrica do corpo, que pode ser medida aplicando-se uma corrente elétrica de pequena amplitude ao paciente.

Uma configuração típica de TIE compreende a disposição de eletrodos em posições específicas ao longo do contorno do objeto estudado. Um padrão de corrente de baixa amplitude é aplicado ao objeto através de um par de eletrodos e os potenciais elétricos resultantes de tal configuração são medidos em todos os eletrodos. Em seguida, o padrão de corrente é alterado, isto é, aplica-se a corrente através de outro par de eletrodos e os potenciais são novamente medidos, e assim sucessivamente, de modo a se obter uma grande quantidade de padrões de potencial elétrico para uma determinada distribuição de condutividade.

A estimativa da distribuição de condutividades de um corpo se trata de um problema inverso, isto é, sua solução consiste em determinar a distribuição de condutividades que implicaria nas medições obtidas por meio das aplicações de corrente. Um problema inverso é complexo de se resolver e mal-posto, por isso muitas vezes sua solução é obtida indiretamente a partir da resolução do problema direto.

Diversos métodos foram utilizados para a reconstrução de imagens com TIE, entre eles o recozimento simulado (Martins and Tsuzuki, 2015; Martins et al., 2014), Gauss Newton (Camargo, 2013), filtro de Kalman (Moura, 2013) e D-Bar (Alsaker and Mueller, 2018). Martins et al. (2019) revisaram os diferentes métodos disponíveis na literatura. A maior parte desses métodos, excluindo-se o método analítico D-bar, resolve o problema inverso a partir do cálculo do problema direto. Dessa forma, a solução é calculada iterativamente e, em geral, tem alto custo computacional e requer muito tempo para a reconstrução de imagens absolutas de TIE.

Este trabalho propõe reconstruções diretas utilizando-se Rede Neurais Artificiais (RNA) a fim de reduzir esse tempo computacional. O problema direto é utilizado para treinar as RNAs, que, uma vez configuradas, são capazes de obter a imagem da TIE de modo direto. Testes preliminares com dados simulados indicam que o algoritmo é capaz de obter uma reconstrução satisfatória de modo direto.

O texto é estruturado da seguinte forma: a Seção 2 descreve o problema da TIE e as abordagens baseadas em RNA para solucioná-lo; a Seção 3 demonstra a formulação da TIE e a solução do problema direto através do método dos elementos finitos (MEF); na Seção 4, as arquiteturas das RNA utilizadas são descritas; o algoritmo proposto para gerar os dados artificiais de treinamento é apresentado na Seção 5; os resultados são reportados na Seção 6 e, por fim, as conclusões apresentadas na Seção 7.

2. REDES NEURAIS ARTIFICIAIS APLICADAS AO PROBLEMA DA TIE

A TIE é um problema inverso, no qual as medições de potenciais nos eletrodos, posicionados ao longo do contorno da região de interesse, são utilizadas para estimar a distribuição interna de condutividades. Esses potenciais são gerados a partir de múltiplas aplicações de correntes em diferentes pares de eletrodos. Esse procedimento pode ser observado na Fig. 1. Nele, padrões de corrente J_i ,

 $i \in [1, 16]$, são aplicados a um domínio com distribuição de condutividade $\sigma(x, y)$. Para cada injeção, o potencial elétrico $\Phi^i_j, \ j \in [1, 16]$, é medido em cada eletrodo i relativamente ao terra.



Fig. 1. A partir da injeção do padrão de corrente J_i , aplicado a um domínio com distribuição de condutividade $\sigma(x, y)$, é possível obter o potencial elétrico Φ_j^i em todos os eletrodos.

O método de reconstrução de imagens adotado neste artigo é o das Redes Neurais Artificiais (RNA). As RNA são formadas por conjuntos de unidades de processamento interligadas, chamadas de neurônios artificiais. De forma análoga à das redes neurais biológicas, nas RNA, quando um sinal é recebido, ele é transmitido e processado ao longo do domínio da rede, gerando uma resposta na saída, conforme a Fig. 2. Os neurônios artificiais podem ou não ser ativados dependendo da intensidade com que são excitados.

No caso da TIE, o sinal aplicado na entrada das RNA é o padrão de potenciais elétricos obtido a partir de uma distribuição de condutividade. A fase de treinamento de uma RNA consiste em estabelecer os pesos sinápticos w_{ij} das ligações entre os neurônios artificiais – isto é, determinar a intensidade de cada ligação na rede – que produzirá, a partir dos dados de potenciais elétricos, a distribuição de condutividade do interior do objeto.

A performance de uma rede neural artificial depende sobretudo de sua capacidade de generalização. Essa capacidade é diretamente afetada pela quantidade de dados disponíveis para o treinamento da rede. Portanto, o ajuste dos pesos sinápticos deve atender simultaneamente a um grande número de conjuntos de potenciais elétricos e distribuições de condutividade. Por isso, obter uma rede que exiba grande acurácia em generalização de dados depende fundamentalmente de uma grande base de dados de treinamento.

As RNA já foram utilizadas para a reconstrução de imagens de TIE. Rymarczyk et al. (2019) utilizaram três configurações distintas de redes alimentadas adiante completamente conectadas. Cada configuração é utilizada para



Fig. 2. Exemplo de uma neural artificial com duas entradas, dois neurônios na camada intermediária e um neurônio na saída. Os pesos sinápticos w_{ij} devem ser ajustados de modo que, a partir das entradas x_i , obtenha-se a saída desejada y.

representar um pixel da imagem reconstruída. Sendo assim, o desempenho do algoritmo depende diretamente da resolução da imagem. Soluções similares, que utilizaram RNA de base radial, foram propostas por Michalikova et al. (2014) e Wang et al. (2009). Outras abordagens para o problema da TIE com RNA incluem o trabalho de Li et al. (2017), que consideraram uma topologia com dois *autoenconders* e uma regressão logística.

Neste trabalho, é proposta a utilização de uma RNA LeNet modificada para a reconstrução de imagens de TIE. Diferentemente de outros trabalhos, a malha do método de elementos finitos é utilizada diretamente na reconstrução das imagens, removendo, assim, a dependência do tamanho da imagem em pixel. Ademais, uma malha mais refinada é utilizada para treinar a RNA, enquanto que uma malha mais grossa é utilizada para a reconstrução. Desse modo, obtém-se um maior controle do desempenho e eficiência do algoritmo.

3. FORMULAÇÃO DO MÉTODO DOS ELEMENTOS FINITOS (MEF) PARA O PROBLEMA DIRETO

O problema bidimensional da TIE é representado pela equação de Laplace

$$\nabla \cdot [\sigma(x,y) \cdot \nabla \Phi(x,y)] = 0 \qquad (x,y) \in \Omega \qquad (1)$$

onde, $\sigma(x, y) \in \Phi$ são as distribuições de condutividade e potencial, respectivamente, e Ω é o domínio do problema. O resultado nulo indica que não existem fontes de corrente no interior do domínio, o que é esperado na TIE (Martins and Tsuzuki, 2015; Martins et al., 2014).

O Método dos Elementos Finitos (MEF) é largamente utilizado para a modelagem de problemas diretos de TIE, dada a sua a capacidade de modelar geometrias e condições de contorno arbitrárias (Dong et al., 2005). No MEF, o domínio é discretizado, gerando uma malha de elementos menores (vide Fig 3). Assim, é possível aproximar as equações do problema para possibilitar a solução em cada elemento. A precisão do método pode ser controlada pelo tamanho do elemento.

Como o elemento triangular foi escolhido para o MEF, uma interpolação polinomial linear é adotada para determinar o potencial no interior do elemento. Desse modo, a matriz de condutividades do elemento, calculada utilizando a notação indicada na Fig. 4, pode ser descrita como



Fig. 3. Exemplos de malha para o problema da TIE.



Fig. 4. Elemento triangular do MEF com nós $i, j \in k$.

$$\begin{split} [K]_{e} &= \sigma_{e} [BC]_{e}^{T} [BC]_{e} \int_{S_{e}} dx dy \\ &= \frac{\sigma_{e}}{4S} \begin{bmatrix} b_{i} & c_{i} \\ b_{j} & c_{j} \\ b_{k} & c_{k} \end{bmatrix} \begin{bmatrix} b_{i} & b_{j} & b_{k} \\ c_{i} & c_{j} & c_{k} \end{bmatrix} \\ &= \frac{\sigma_{e}}{4S} \begin{bmatrix} b_{i}^{2} + c_{i}^{2} & b_{i}b_{j} + c_{i}c_{j} & b_{i}b_{k} + c_{i}c_{k} \\ b_{j}b_{i} + c_{j}c_{i} & b_{j}^{2} + c_{j}^{2} & b_{j}b_{k} + c_{j}c_{k} \\ b_{k}b_{i} + c_{i}c_{k} & b_{k}b_{j} + c_{k}c_{j} & b_{k}^{2} + c_{k}^{2} \end{bmatrix}, \end{split}$$
(2)

onde

$$a_{i} = x_{j}y_{k} - x_{k}y_{j} \ a_{j} = x_{k}y_{i} - x_{i}y_{k} \ a_{k} = x_{i}y_{j} - x_{i}y_{j}$$

$$b_{i} = y_{j} - y_{k} \ b_{j} = y_{k} - y_{i} \ b_{k} = y_{i} - y_{j}$$

$$c_{i} = x_{k} - x_{i} \ c_{i} = x_{i} - x_{k} \ c_{k} = x_{j} - x_{i}.$$
(3)

A matriz do elemento $[K]_e$ deve ser calculada para todos os elementos da malha. Em seguida, deve-se aglomerarálas de acordo com o número de nós, gerando uma matriz global de condutividade K. A formulação do MEF para o problema direto de TIE se reduz à resolução de um sistema linear de equações

$$K \cdot \Phi = I \tag{4}$$

onde, I é o vetor de correntes injetadas e Φ é o vetor de potenciais a ser calculado. Ambos os vetores têm



Fig. 5. Exemplo de MaxPooling com filtro de tamanho 2×2 e passo de $2\times 2.$

cardinalidade n,que corresponde ao número de nós da malha. A matriz Ktem cardinalidade $n\times n$ e é simétrica e esparsa.

4. REDES NEURAIS CONVOLUCIONAIS

O método proposto neste trabalho se baseia na arquitetura de RNA convolucionais LeNet (Lecun et al., 1998). Três etapas caracterizam usualmente esse tipo de RNA: convolução, função de ativação e *pooling*. Além dessas, a arquitetura LeNet modificada ainda apresenta uma camada completamente conectada.

As RNA convolucionais são bem adaptadas para trabalhar com imagens, que possuem duas dimensões. Assim, os dados de entrada, ou seja, os potenciais medidos, são convertidos para uma matriz de dimensão $n_e \times n_e$, onde n_e é o numero de eletrodos. Depois, na etapa de convolução, são aplicados filtros que são capazes de aprender a identificar características dos dados de entrada. Finalmente, na etapa de *pooling*, um filtro é aplicado a fim de substituir um conjunto de valores pelo seu valor máximo, como mostrado na Fig. 5.

4.1 Proposta com a arquitetura LeNet modificada

A rede LeNet foi originalmente proposta para um problema de classificação, que é mais simples do que o tratado aqui e possui menos parâmetros. Desse modo, é proposta uma nova arquitetura adaptada, esquematizada na Fig. 6.

A arquitetura modificada da rede neural convolucional possui 7 camadas:

- (1) camada de entrada, que compreende os dados de 32 eletrodos;
- (2) camada de convolução com 30 filtros de tamanho 5×5 , função de ativação ReLU, saltos de 2×2 e padding;
- (3) camada de *pooling* com kernels de tamanho 2×2 , saltos de 2×2 e *padding*;
- (4) segunda camada de convolução, similar à primeira, mas com 60 filtros;
- (5) segunda camada de *pooling*, idêntica à primeira;
- (6) camada escondida totalmente conectada com 355 neurônios, que achata os dados e possui função de ativação ReLU e
- (7) camada de saída com função de ativação ReLU, que possui o número de neurônios equivalente ao número de nós da malha não refinada.

5. GERAÇÃO DE DADOS SINTÉTICOS

A solução do problema direto da TIE pelo MEF fornece a distribuição de potenciais dados os padrões de correntes e



Fig. 6. Proposta de arquitetura modificada para a rede LeNet.

a condutividade do meio. Assim, a partir de distribuições de condutividade geradas sinteticamente, é possível então calcular os potenciais elétricos decorrentes da aplicação de um padrão de corrente. Esses dados podem, então, ser utilizados para o treinamento das RNA. Uma vez que a rede neural tenha sido treinada, é possível fornecer medidas de potencial elétrico e obter uma estimativa de distribuição de condutividade em tempo mínimo.

A qualidade das imagens reconstruídas é afetada pelo nível de discretização da malha utilizada para o cálculo dos potenciais. Por isso essas malhas devem ter alta densidade, de modo que os erros de discretização sejam minimizados.

Para a geração dos dados sintéticos de treinamento, primeiro criam-se duas malhas para a representação das condutividades: uma refinada e outra grosseira. O problema direto é resolvido na malha refinada, enquanto que a reconstrução é realizada na malha grosseira.

Os dados de treinamento são gerados a partir das seguintes etapas:

- geração das malhas refinada e grosseira para um domínio esperado do experimento;
- (2) definição da distribuição das condutividades nos nós das duas malhas, baseadas na geometria esperada do experimento e na condutividade do meio;
- (3) solução do problema direto pelo MEF utilizando a malha refinada para todos os padrões de corrente;

O conjunto de potenciais obtidos no passo 3 e a distribuição de condutividades na malha grosseira determinada no passo 2 são os dados utilizados no treinamento da rede neural convolucional proposta.

6. RESULTADOS

A rede neural convolucional proposta foi testada utilizando dados sintéticos, gerados pelo algoritmo apresentado na Seção 5. Foi considerado um experimento em que três fantomas circulares de condutividade relativamente baixa são posicionados em uma cuba circular preenchida com uma solução salina. Ao longo do contorno da cuba foram posicionados 32 eletrodos de modo equidistante.

Foram gerados 30000 dados de treinamento para o experimento simulado descrito. A partir desse conjunto foram gerados 6 subconjuntos de dados. O primeiro contém 5000 dos 30000 dados gerados. O segundo, 10 dos 30 mil dados, incluindo os 5000 anteriores, e assim sucessivamente. O sexto subconjunto contém todos os 30000 dados de treinamento.

Seis redes neurais convolucionais foram treinadas a partir da arquitetura proposta e dos subconjuntos apresentados anteriormente. As demais características de treinamento foram:

- tamanho do lote: 100;
- épocas: 100;
- conjunto de validação: 20% dos dados de treinamento foram separados para a estimação dos erros de teste;
- parada antecipada ativada;
- otimizador: Adam;
- função objetivo: erro quadrático médio.

Na Fig. 7, compara-se os erros nos conjuntos de validação calculados para as 6 redes convolucionais. Pode-se observar que os erros diminuem rapidamente com o aumento do conjunto de dados e, em seguida, se estabilizam.





O experimento foi repetido para o subconjunto de 30000 dados, porém, dessa vez, o número de épocas foi aumentado para 200. A Fig. 8 apresenta a evolução do erro quadrático médio no conjunto de validação em função do número de épocas.

Um conjunto de 4 dados de treinamento foi gerado para a avaliação visual dos resultados. Na Fig. 9, o domínio real do problema é apresentado à esquerda, enquanto a imagem reconstruída a partir da rede convolucional é apresentada à direita. O erro quadrático médio no conjunto de teste foi de $1, 37 \cdot 10^{-3}$.



Fig. 8. O erro quadrático médio mínimo obtido nos dados de validação em função do número de épocas.



Fig. 9. Comparação entre a distribuição de condutividades no domínio real (à esquerda) e a distribuição de condutividades obtida pela CNN.

7. CONCLUSÕES E TRABALHOS FUTUROS

Foi proposta uma solução baseada em RNA para o problema da TIE. O treinamento da rede neural convolucional foi realizado usando duas malhas diferentes. A malha mais fina foi utilizada para se obter os potenciais com maior exatidão, enquanto que a malha mais grossa foi utilizada para a reconstrução da distribuição de condutividades. Como diferencial, os resultados obtidos não estão associados a nenhuma resolução.

Foram gerados resultados a partir de dados sintéticos para diferentes parâmetros de treinamento. A partir de um conjunto de quatro dados de testes, foi possível verificar visualmente a alta qualidade dos resultados da reconstrução da TIE. Além disso, para esse conjunto, foi verificado um erro relativamente baixo.

Neste trabalho somente a parte real das condutividades foi considerada. Como trabalho futuro, os efeitos capacitivos e anisotrópicos devem ser também observados (Martins and Tsuzuki, 2017). O caso tridimensional é uma expansão natural do problema. Pesquisas adicionais podem incluir o posicionamento incorreto dos eletrodos e a geometria irregular do contorno.

REFERÊNCIAS

- Alsaker, M. and Mueller, J.L. (2018). Use of an optimized spatial prior in D-bar reconstructions of EIT tank data. *Inverse Probl Imag*, 12(4), 883–901.
- Camargo, E.D.L.B. (2013). Desenvolvimento de algoritmo de imagens absolutas de Tomografia por Impedância Elétrica para uso clínico. Phd thesis, EPUSP, São Paulo.
- Dong, G., Zou, J., Bayford, R.H., Ma, X., Gao, S., Yan, W., and Ge, M. (2005). The comparison between fvm and fem for eit forward problem. *IEEE T Magn*, 41(5), 1468–1471.
- Geuzaine, C. and Remacle, J.F. (2009). Gmsh: A 3-D finite element mesh generator with built-in pre- and postprocessing facilities. Int J Numer Meth Eng, 79(11), 1309–1331.
- Lecun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proc IEEE*, 86(11), 2278–2324.
- Li, X., Lu, Y., Wang, J., Dang, X., Wang, Q., Duan, X., and Sun, Y. (2017). An image reconstruction framework based on deep neural network for electrical impedance tomography. In 2017 IEEE ICIP, 3585–3589.
- Martins, T.C. and Tsuzuki, M.S.G. (2012). Electrical impedance tomography reconstruction through simulated annealing with total least square error as objective function. In *Proc 34th IEEE EMBC*, 1518–1521. San Diego, USA.
- Martins, T.C. and Tsuzuki, M.S.G. (2015). EIT image regularization by a new multi-objective simulated annealing algorithm. In *Proc 37th IEEE EMBC*, 4069–4072. Milan, Italy.
- Martins, T.C., Fernandes, A.V., and Tsuzuki, M.S.G. (2014). Image reconstruction by electrical impedance tomography using multi-objective simulated annealing. In *IEEE 11th ISBI*, 185–188. Beijing, China.
- Martins, T.C. and Tsuzuki, M.S.G. (2017). Investigating Anisotropic EIT with Simulated Annealing. *IFAC-PapersOnLine*, 50(1), 9961–9966.
- Martins, T.C., Sato, A.K., Moura, F.S., Camargo, E.D.L.B., Silva, O.L., Santos, T.B.R., Zhao, Z., Möeller, K., Amato, M.B.P., Mueller, J.L., Lima, R.G., and Tsuzuki, M.S.G. (2019). A review of electrical impedance

tomography in lung applications: Theory and algorithms for absolute images. *Annu Rev Control.* doi:https://doi. org/10.1016/j.arcontrol.2019.05.002.

- Michalikova, M., Abed, R., Prauzek, M., and Koziorek, J. (2014). Image reconstruction in electrical impedance tomography using neural network. In 2014 CIBEC, 39– 42.
- Moura, F.S. (2013). Estimação não linear de estado através do Unscented Kalman Filter na tomografia por impedância elétrica. Phd thesis, EPUSP, São Paulo.
- Rymarczyk, T., Kłosowski, G., Kozłowski, E., and Tchórzewski, P. (2019). Comparison of selected machine learning algorithms for industrial electrical tomography. *Sensors (Basel)*, 19(7), 1521.
- Silva, O.L., Lima, R.G., Martins, T.C., Moura, F.S., Tavares, R.S., and Tsuzuki, M.S.G. (2017). Influence of current injection pattern and electric potential measurement strategies in electrical impedance tomography. *Control Eng Pract*, 58, 276–286.
- Wang, P., Li, H., Xie, L., and Sun, Y. (2009). The implementation of FEM and RBF neural network in EIT. In 2009 ICINIS, 66–69.